«Подсистема энтропийного кодирования при сжатии информации»

Схема работы GDCT кодека

Сжатие информации

Методы Сжатия информации

С потерями

Без потерь

Стратегии сжатия

- *Статистическая стратегия* сжатия предполагает определение вероятностей элементов.
- В *блочных* методах статистика элементов отдельно кодируется и добавляется к сжатому блоку.
- В *поточных* (адаптивных) методах вычисление вероятностей для элементов поступающих данных производится на основе априорных вероятностей из предыдущих данных.
- *Преобразующая стратегия* не предполагает вычисления вероятностей. Результат преобразования имеет лучшую структуру данных и может быть сжат простым и быстрым методом

Классификация методов сжатия

	Статистические		Преобразующие	
	Поточные	Блочные	Поточные	блочные
Модель «*источник без памяти*» (поток *элементов*)	Адаптивный HUFFMAN	Статистический HUFFMAN	SEM, VQ, MTF, DC, SC, DWT	DFT, DCT
Модель «*источник с памятью*» (поток *слов*)	CM, DMC, PPM	CMBZ, precon-ditioned PPMZ	LZ*	BWT, ST
Модель *элементов* или *битов*	Адаптивный ARIC	Статистический ARIC	RLE, LPC	PBS, ENUC

Расшифровка названий методов

- CM (Context modeling) – контекстное моделирование.
- DMC (Dynamic Marcov compression) – динамическое марковское сжатие
- (частный случай CM)
- PPM (Predictio by partial match) –предсказание по частичному совпадению (частный случай CM).
- LZ* (LZ77, LZ78, LZH, LZW) – методы Зива – Лемпеля.
- HUFFMAN (Huffman coding) – кодирование Хаффмана.
- RLE (Run length encoding) – кодирование длин повторов.
- SEM (Separate exponents and mantissas) – разделение экспонент и мантисс
- (представление целых чисел).
- UNIC (Universal coding) – универсальное кодирование
- (частный случай SEM).
- ARIC (Arithmetic coding) – арифметическое кодирование.
- RC (Range coding) – интервальное кодирование
- (вариант арифметического кодирования).

Расшифровка названий методов

- DC (Distance coding) – кодирование расстояний.
- IF (Inversion frequencies) – «обратные частоты» (вариант DC).
- MTF (Move to front) – «сдвиг к вершине», «перемещение стопки книг».
- ENUC (Enumerate coding) – нумерующее кодирование.
- DFT (Discrete Fourier transform) – ДПФ- дискретное преобразование Фурье
- DCT (Discrete cosine transform) – ДКП – дискретное косинусное преобразование
- DWT (Discrete wavelet transform) – дискретное вейвлет – преобразование.
- LPC (Linear prediction coding) – кодер линейного предсказания.
- PBS (Parallel blocks sorting) – сортировка параллельных блоков.
- ST (Sort transformation) – частичное сортирующее преобразование
- (частный случай PBS)
- BWT (Burrows – Wheeler transform) – преобразование Барроуза – Уиллера (частный случай ST)

Характеристики сжатия

- а) *фактор сжатия* $r = FS/F0$,
- б) *коэффициент сжатия* $k = F0/FS = 1/r$,
- в) *качество сжатия* $\eta = 100(1-r) = 100(F0-FS)/FS$.
- Здесь F0 и FS – размеры исходного и выходного (сжатого файлов).
- Очевидно, что при $r<1$, $k>1$ происходит сжатие выходного файла. Параметр $\eta<100$ показывает относительное уменьшение в процентах сжатого файла по сравнению с исходным файлом.

Энтропия сообщения по К.Шеннону – bps (bit per symbol)

$$H = -\sum_{i=1}^{N} P_i \cdot \log_2(P_i)$$

Теоретический предел длины сжатого сообщения

$$L' = n \cdot H$$

$$L' = -n \sum_{i=1}^{N} P_i \cdot \log_2(P_i)$$

$$L = n \cdot l,$$

длина символа в битах

число символов

Пример расчета энтропии сообщения длины сжатого сообщения и коэффициента сжатия

- Сообщение :
- *Длинношеее животное*
- Частоты символов

symbol	д	л	и	н	о	ш	е	ж	в	т	
k_i	1	1	2	3	3	1	4	1	1	1	1

- Число символов n=19
- Энтропия H=3.221 bps
- Длина сжатого сообщения $L'=n \cdot H=61.201$ bit
- Длина исходного сообщения $L=n \cdot 8=152$ bit
- Коэффициент сжатия k=2.484

Пример расчета энтропии сообщения длины сжатого сообщения и коэффициента сжатия

- Сообщение :
- *2718281828*
- Частоты символов

symbol	2	7	1	8
k_i	3	1	2	4

- Число символов n=10
- Энтропия H=1.846 bps
- Длина сжатого сообщения $L'=n \cdot H=18.46$ bit
- Длина исходного сообщения $L=n \cdot 8=80$ bit
- Коэффициент сжатия k=4.33

Некоторые методы сжатия без потерь

Энтропийное кодирование

Кодирование Хаффмана

Арифметическое кодирование

Кодирование длин непрерывных Последовательностей (RLE)

Кодирование длин непрерывных последовательностей (RLE)

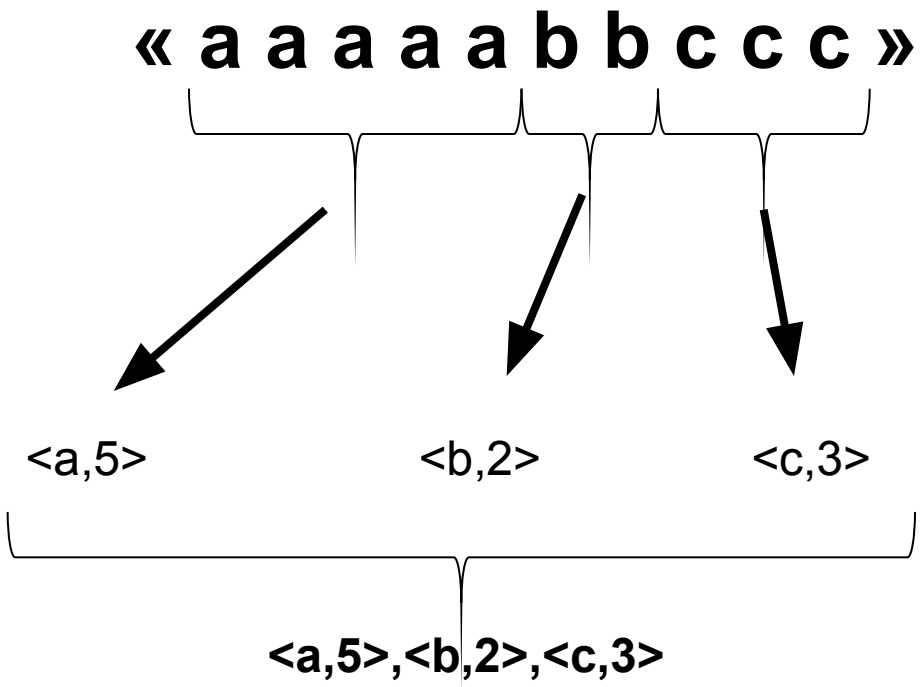

Алгоритм кодирования Хаффмана

«aabac» = 00 00 01 00 10

10 бит

Таблица вероятностей:

a	b	c
00	01	10
0.6	0.2	0.2

L’=6.855 бит

Построение дерева Хаффмана

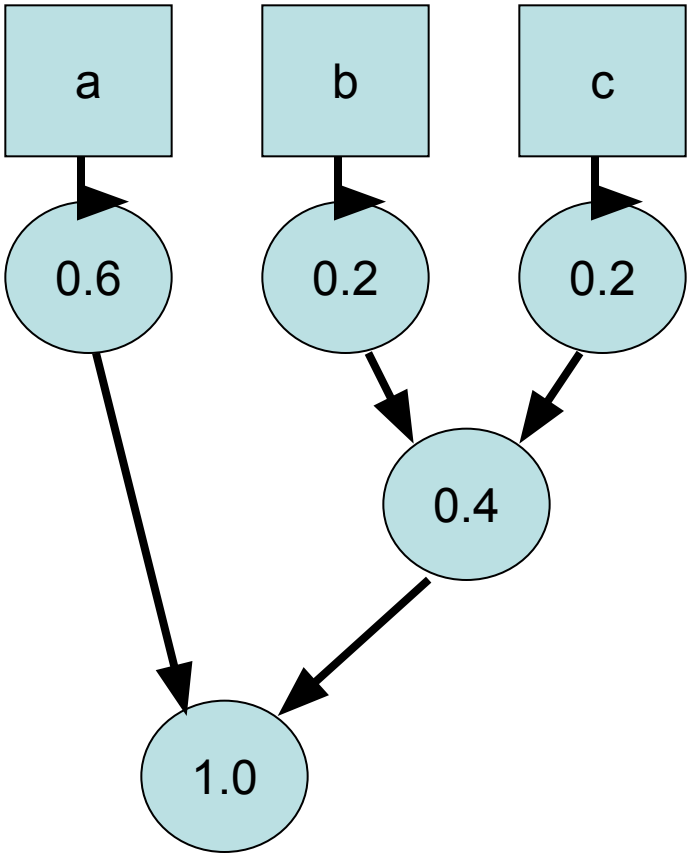

Кодирование Хаффмана

Дерево Хаффмана

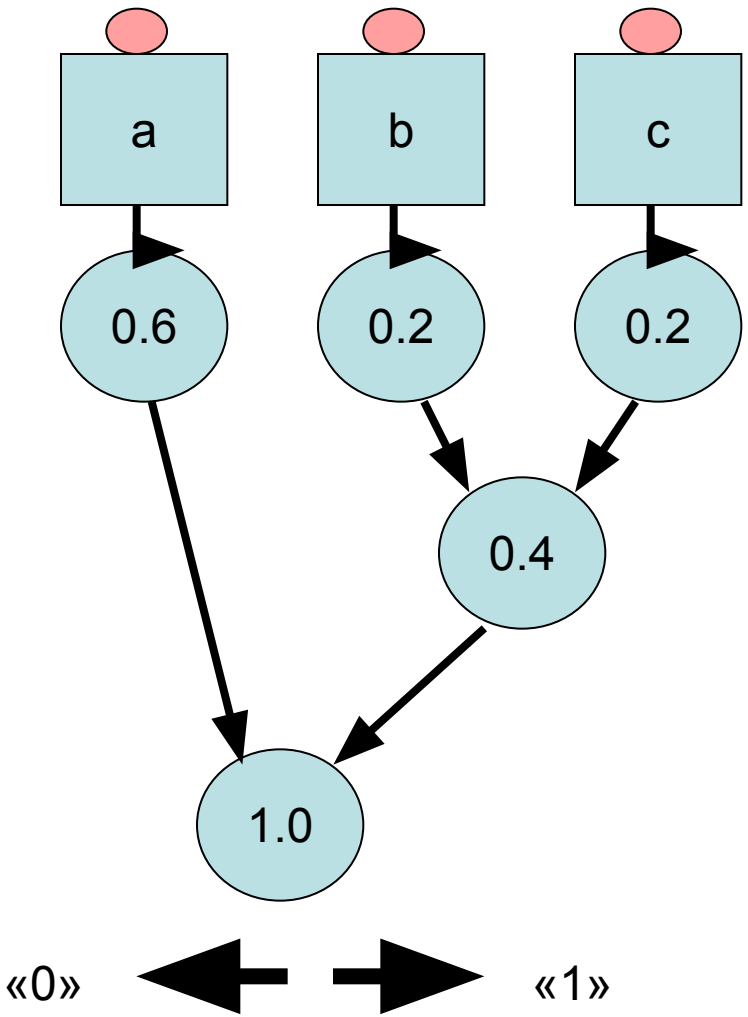

Коды Хаффмана

‘a’ - «0»

‘b’ - «10»

‘c’ - «11»

«a a b a c»

0 0 10 0 11

7 бит (L’=6,855 бит)

0 - движение по левой ветви
1 - движение по правой ветви

Декодирование Хаффмана

Дерево Хаффмана

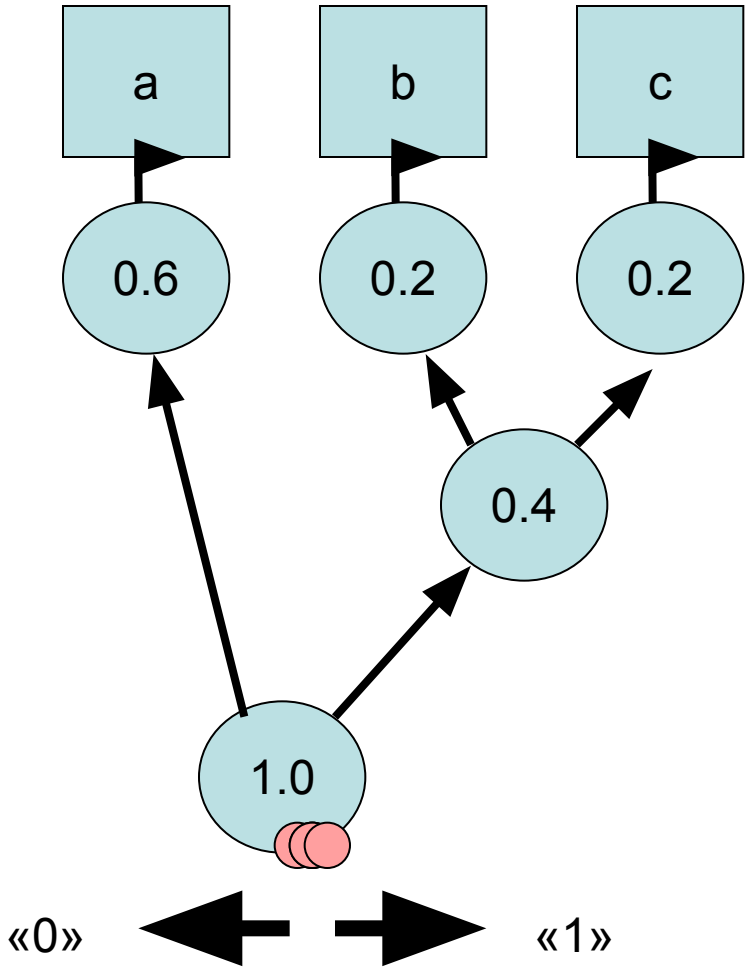

Последовательность кодов Хаффмана:

0 0 1 0 0 1 1

0 - a

0 - a

1 0 - b

0 - a

1 1 - c

Сообщение восстановлено

«a a b a c»

0 - движение по левой ветви
1 - движение по правой ветви

Дерево Хаффмана – 1 вариант

- Код
- 0
- 10
- 111
- 1101
- 1100

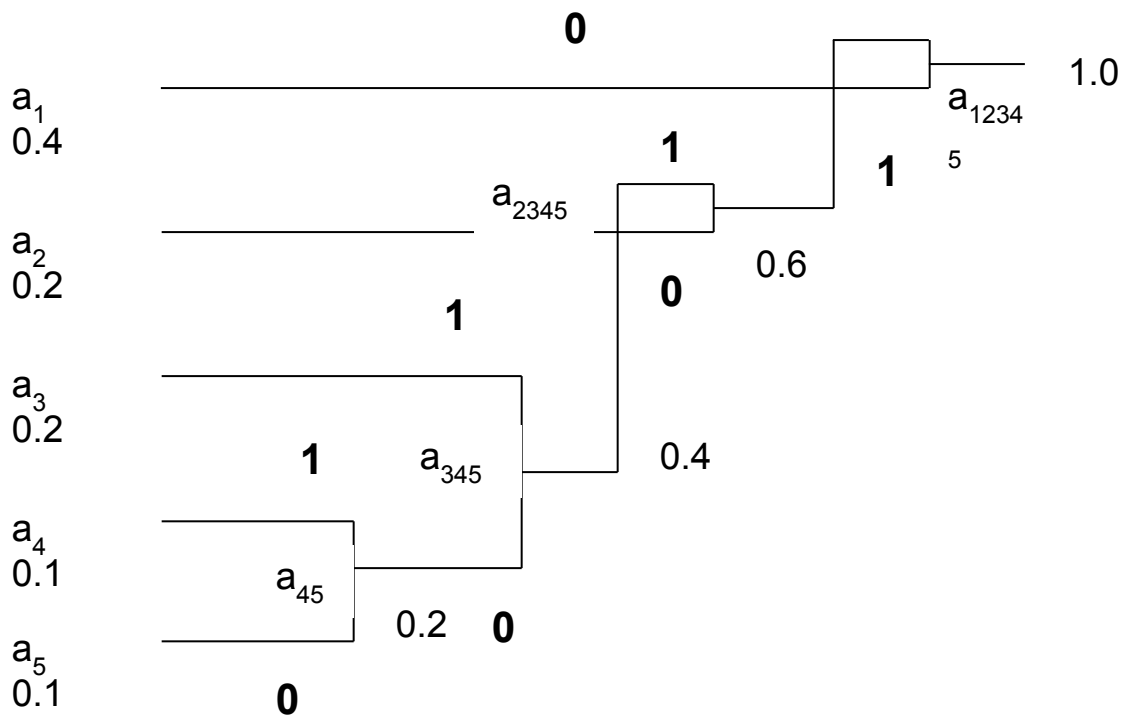

- Энтропия H=2.2 bps дисперсия длин кодов 1.36

Дерево Хаффмана – 2 вариант

- Код
- 11
- 01
- 00
- 101
- 100

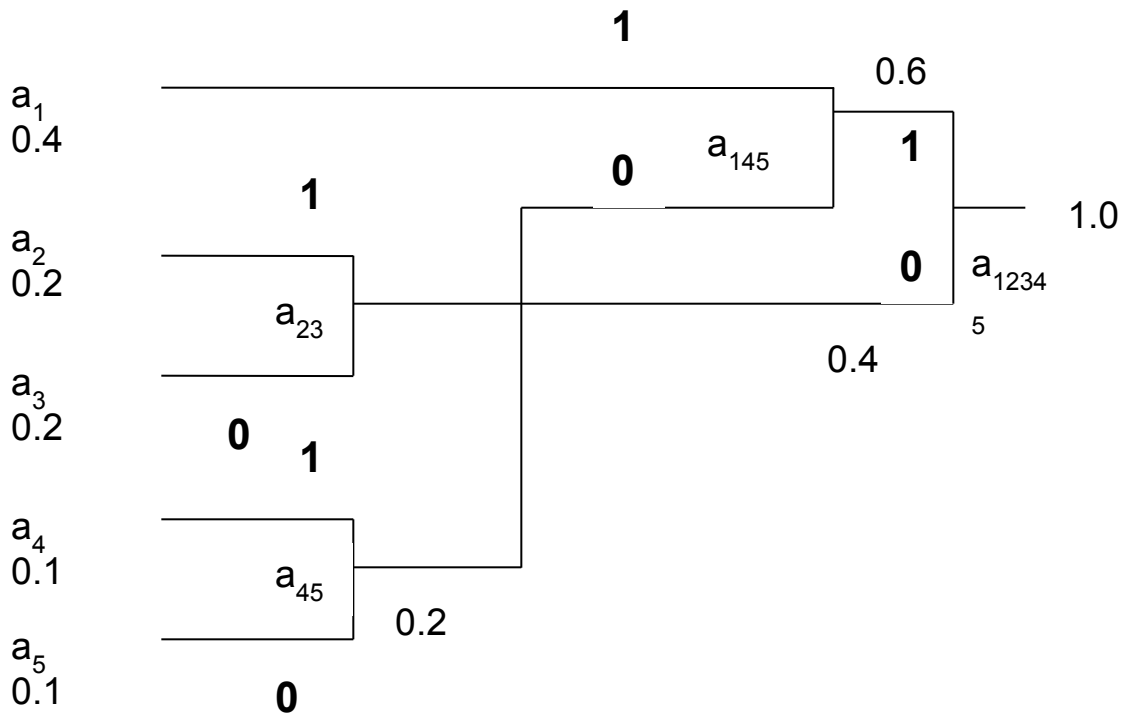

- Энтропия H=2.2 bps, Дисперсия длин кодов 0.16

Дисперсия длин кодов

- Средняя длина кода

$$H = -\sum_{i=1}^{N} P_i \cdot \log_2(P_i)$$

- l_i - длина i-го кода в битах

- Дисперсия кода

$$D = \sum_{i=1}^{n} p_i (l_i - H)^2$$

- В стандартах используют готовые коды VLC (коды переменной длины)

Арифметическое кодирование

Таблица вероятностей:

«aabc»

a	b	c
0.5	0.25	0.25

L’=6

Результат:
Любая двоичная дробь
из интервала [0,171875; 0.1875)
Например, 0.171875

Арифметическое кодирование

«aabc»

Таблица вероятностей:

a	b	c
0.5	0.25	0.25

Результат:
Любая двоичная дробь
из интервала [0,171875; 0.1875)
Например, 0.171875

Выходной поток: 0.171875d=0.001011b=«001011»

Сравнение кодов

- VLC – удобны для реализации, не универсальны, средняя длина отлична от энтропии
- Двухпроходные коды Хаффмана – средняя длина кода близка к энтропии, информация о дереве должна присоединяться к сжатой информации.
- Просты в программировании
- Адаптивные коды Хаффмана не требуют априорных сведений о вероятностях символов, компрессор и декомпрессор должны быть идентичными
- Арифметический кодер – средняя длина кода практически равна энтропии. Достаточно сложен в программировании. Требования априорных сведений , как у кода Хаффмана. Дерево кодирования-декодирования однозначно

Исходное изображение «Masha»

Результат восстановления

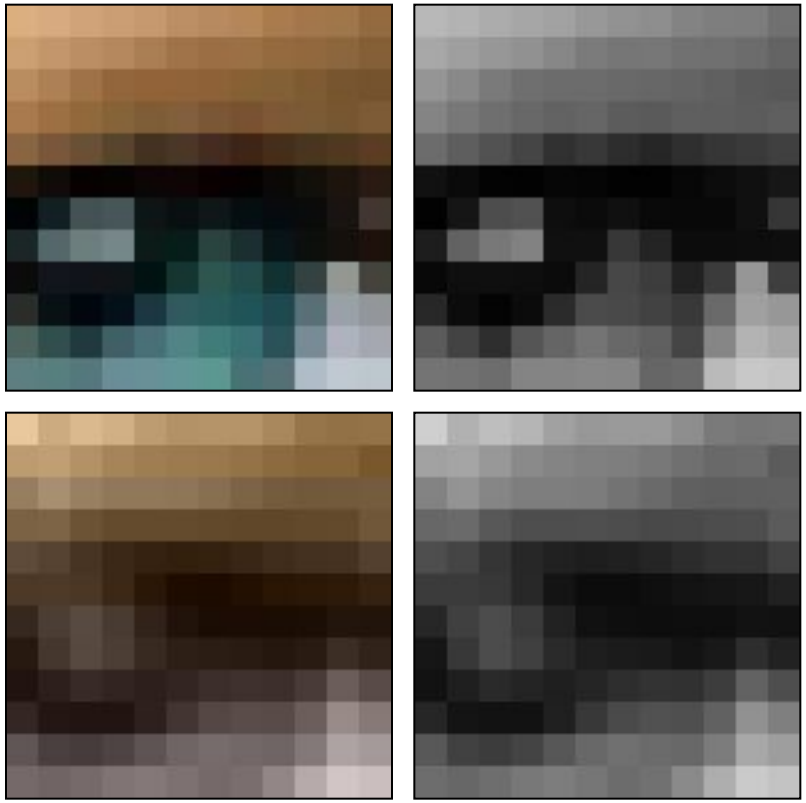

RLE: 14953 байт (сжатие: 25,29)
RLE+Huffman: 11047 байт (сжатие: 34,24)
RLE+Arithm: 11022 байт (сжатие: 34,32)

PSNR(Y)=20,578 дБ, сжатие: 34,32

Результат восстановления

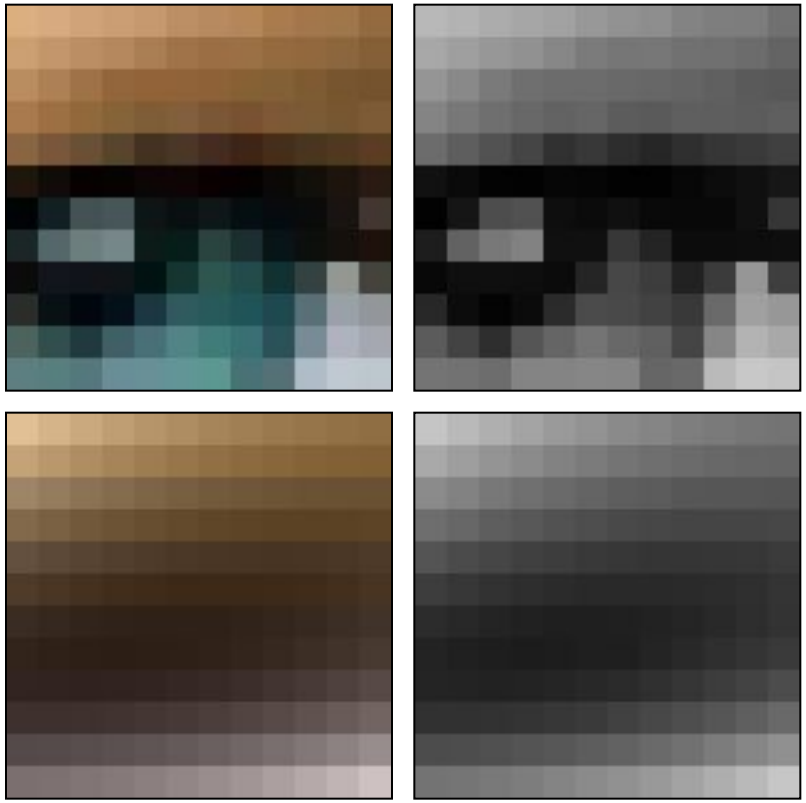

RLE: 5929 байт (сжатие: 63,80)
RLE+Huffman: 4229 байт (сжатие: 89,44)
RLE+Arithm: 4209 байт (сжатие: 89,87)

PSNR(Y)=19,752 дБ, сжатие: 89,87